

基于模糊神经网络的电动汽车再生制动控制方法

杨品海

南京工程学院, 江苏 南京 211167

摘要: 电动汽车凭借其零排放、低噪音和高能效等优势, 成为推动绿色出行的重要选择。然而, 由于动力电池技术的限制, 电动汽车的续航里程仍难以满足用户需求, 严重制约了其推广和普及。为提高电动汽车的能量利用效率, 制动能量回收技术应运而生, 通过在制动过程中回收动能并将其存储于动力电池中, 实现能量的循环利用。

关键词: 电动汽车; 模糊神经网络; 再生制动

DOI:10.63887/jeti.2025.1.3.30

1 引言

为应对能源安全与环境污染的双重挑战, 国家大力推动绿色低碳转型, 并提出到 2030 年前力争实现碳达峰、2060 年前实现碳中和的宏伟目标。新能源汽车具有零排放、高能效、低噪音等显著优势, 有助于减少交通领域的碳排放并优化能源结构, 因此被视为实现这一目标的重要抓手^[1]。再生制动系统作为电动汽车提高能量利用效率、延长续航里程的重要组成部分, 能够在制动过程中将动能回收并转化为电能储存在动力电池中^[2]。然而, 传统再生制动控制方法普遍存在控制精度不高、响应迟缓、能量回收效果不稳定等问题, 尤其在复杂多变的实际工况下, 如低速拥堵、坡道滑行或频繁启停等, 制动控制容易出现突变、迟滞或能量回收效率下降, 甚至影响驾驶安全性与舒适性^[3]。

因此, 亟需一种具备自适应学习能力、能够融合多源输入信息并实现动态优化的再生制动控制方法, 以提升电动汽车在多种典型工况下的能量回收效率和制动平稳性^[4]。

2 再生制动原理

相比于传统燃油汽车, 电动汽车具备独特的制动能量回收优势, 在减速或制动过程中,

可将部分动能高效转化为电能并存储, 存储于动力电池中, 实现能量的循环利用。这一技术在一定程度上延长了车辆的续驶里程, 有助于提升电动汽车的经济性和实用性。再生制动系统在提供必要的制动减速功能的同时, 能够有效降低制动系统的热负荷, 减少传统摩擦制动器的使用频率, 进而降低摩擦片的磨损程度, 改善制动系统的抗热衰退性能, 延长制动系统的使用寿命。此外, 通过优化制动能量回收策略, 能够实现电动汽车制动过程的能量管理, 平衡动力性能与舒适性, 提升整车的操控稳定性, 进一步推动电动汽车向高效、节能、环保的方向发展^[5]。

电动汽车制动系统通过整车控制器协调电机再生制动力与液压制动力分配, 实现安全制动与能量回收。当驾驶员踩下制动踏板时, 控制单元触发电机产生反向制动转矩, 并将回馈电流输送至储能系统, 同时根据传感器数据与控制策略精准计算制动力矩, 以优化制动效果与整车性能

3 车辆数据采集

通过车载控制器 (Vehicle Control Unit, VCU) 实时采集整车关键运行状态参数。对上述原始信号进行滤波和预处理, 剔除异常值和

干扰噪声,采用中值滤波或滑动平均算法确保数据稳定性与实时性。对采集的连续数据进行归一化处理,以便后续模糊控制器和神经网络模型进行统一量纲输入,提高算法处理效率与精度。将处理后的多源车辆运行参数组成输入向量,作为模糊控制系统与神经网络控制器的联合输入,为制动控制决策提供完整、准确的工况信息基础。

4 模糊控制器构建

将上述参数输入模糊控制器,基于隶属函数与模糊推理规则输出初步再生制动目标值。

4.1 最大能量回收效率分析

假设车辆完成纵向动力学,且路面附着系数相同的情况下有:

$$J\omega_f = r_e F_{xf} - \sum T_f \quad (1)$$

其中, ω_f 表示车轮转角速度; r_e 表示车辆轮胎的半径; F_{xf} 表示车辆轮胎的纵向力; T_f 为制动力。

将上式进行离散化处理后可以得到:

$$\omega_f(k+1) = \frac{\Delta t}{J} \left[r_e F_{xf}(k) - \sum T_f(k) \right] + \omega_f(k) \quad (2)$$

为了确保电动汽车制动安全性的同时最大化能量回收效率,需要使电机参与再生制动所产生的功率达到最大,因此引入函数 J_{opt} 进行优化:

$$J_{opt} = \min \frac{1}{K} \quad (3)$$

系统的约束条件为:

$$\begin{cases} T_{re} \leq T_{lim} \\ 0 \leq SOC \leq SOC_{max} \\ 0 \leq z \leq z_{max} \end{cases}$$

其中, T_{re} 为电机产生的实际转矩; T_{lim} 为电机允许的最大制动转矩; SOC_{max} 为电池

允许进行再生制动的最大荷电量; z_{max} 为确保制动安全稳定性的最大制动强度。

综上,为了在电动汽车制动过程中最大化能量回收效率,需要优化再生制动的回收比例,使其系数 K 尽可能接近最大值,从而提高整体能量回收效果并提升系统运行效率。

4.2 模糊规则库推理

(1) 制动强度反映了车辆在制动时的紧急程度。根据一般的制动原理,电动汽车的制动强度越小,车辆运行更加安全可靠,此时可以进行完全的电机制动以提高制动时的能量回收效率,不过整体制动力也相对较低,回收程度有限。电动汽车的制动强度越大,电机制动的介入程度通常越高,但此时还要考虑制动的安全性。将制动强度 z 的模糊阈值设置为 $(0, 1)$, 模糊集为 (L, M, H) 。

(2) 车速直接反映了电机的转速,同时影响电机的再生制动转矩。在制动过程中,低车速下虽然电机输出的制动力矩较小,但整体运行更为稳定和安全;而在高速状态下,可参与回收的再生制动转矩增大,获取的能量更多,但相应的安全风险也会提高。将 v 的模糊阈值设置成 $(0, 120)$, 模糊集为 (L, M, H) 。

(3) 电池 SOC 是影响再生制动能量回收的重要因素。为避免对电池寿命造成影响,当 SOC 水平较高时,应尽量减少充电。而在 SOC 较低的情况下,电池电压相对较低,此时进行充电更安全且能量回收效率更高。SOC 的模糊阈值设置为 $(0, 1)$, 模糊集为 (L, M, H) 。

5 模糊神经网络

将模糊控制器的输出与实际运行状态参数输入神经网络控制模块,基于误差反向传播算法优化控制量,输出最终再生制动指令。模糊神经网络控制器结构如图 1 所示。

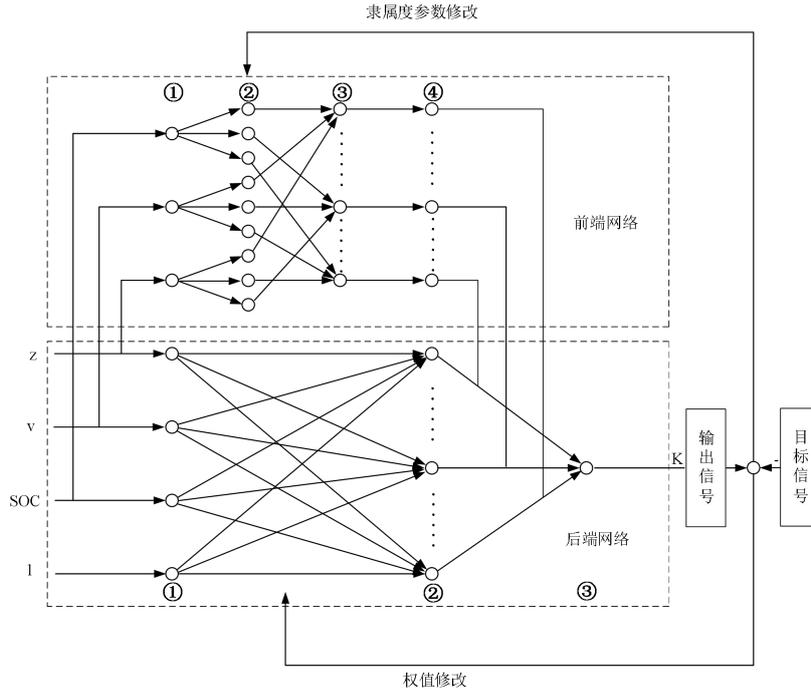


图 1 模糊神经网络控制器

(1) 构建用于模糊规则匹配的前端网络。前端网络第一层为输入层。用于将系统中准确的控制变量输入至下一层，作为模糊神经网络控制器训练的输入样本。存在 3 个神经元，为：

$$x = [x_1, x_2, x_3]^T \quad (5)$$

其中， x_1 , x_2 , x_3 分别表示当前车辆的制动强度 z , 车速 v 和电池 SOC 的真实输入值。

第二层为隶属度函数分配层，用于将第一层输入的精确变量转化为模糊控制变量。模糊化的处理方式选用高斯函数。第一层的三个输入变量在第二层经过划分成为 9 个神经元，可以表示为：

$$\mu_i^j = \mu_{A_i^j}(x_i) \quad (6)$$

其中， i 表示第一层节点产生的值的序号， j 表示模糊集合个数。

第三层为模糊推理层，其节点分别对应上一层中的某一模糊集合，共计包含 27 个节点。根据匹配规则的设定，对上述 27 个节点进行适应度数值计算：

$$\alpha_j = \min\{\mu_1^j, \mu_2^j, \mu_3^j\} \quad (7)$$

其中， α_j 表示第 j 层的适应度， i_1, i_2, i_3 分别表示第二层隶属度分配标准下个数， $j = 27$ 。

第四层负责归一化处理，为确保输出变量的统一标准，生成的节点数量需与上一层保持一致，如下：

$$\bar{\alpha}_j = \frac{\alpha_j}{\sum_{i=1}^{27} \alpha_j} \quad (8)$$

(2) 构建用于规范输出的后端网络。后端网络在结构上与神经网络保持高度一致，在功能上是用来处理参数的归一化，一共分为三层。

第一层为输入层。该层共设计 4 个处理节点，其中包含制动强度 z 、车速 v 、电池 SOC 以及一个恒定常数 1。

第二层为隐藏层。其节点与模糊规则数相对应，同样有 27 个节点，用于计算条件规则的后端值，为：

$$y_j = q_{j0} + q_{j1}x_1 + q_{j2}x_2 + q_{j3}x_3 \quad (9)$$

第三层为输出层。经过模糊神经网络计算

后的输出值即为再生制动力分配系数 K 。

$$y = k = \sum_{j=1}^{27} \overline{\alpha_j} y_j \quad (10)$$

神经网络在控制过程中不断接收来自车辆实际运行的反馈数据（如实际制动减速度、电机制动力、踏板响应偏差等），将其作为监督信号根据上述对网络参数进行在线修正。

6 仿真验证

以电动汽车典型制动工况为研究对象，结合实际车辆运行参数进行分析。利用车辆动力系统模型、电机制动特性及电池充放电能力进行联合仿真。通过在 MATLAB/Simulink 平台中搭建基于模糊神经网络的再生制动控制系统模型，输入实际的车速、电机转速、电池荷电状态 (SOC)、制动踏板开度等参数，在 CRUISE 平台中对控制方法的能量回收效率进行定量分析与对比验证。

本文选取 NEDC (New European Driving Cycle) 工况，即新欧洲驾驶循环测试，是在欧洲、中国及澳大利亚广泛应用的标准测试方法，常用于我国工信部对传统燃油汽车油耗及电动汽车续航里程的评估。

NEDC 工况仿真结束后，对比分析了 Cruise 自带控制策略、模糊控制策略和模糊神经网络再生制动控制策略对电池 SOC 消耗的影响，以及对回收能量的影响。如图 2 和图 3 所示。相较于 Cruise 自带控制策略和传统模糊控制策略，采用模糊神经网络控制策略后，电池 SOC 的消耗得到了明显优化，且能够回收更多的能量。具体数据详见表 1。

在单个 NEDC 工况循环中，根据初始设定

的 SOC 起始值为 75%，Cruise 自带控制策略下电池 SOC 从 75%降低到 65.28%，消耗为 9.72%；基于模糊控制的策略使电池 SOC 从 75%降低到 66.05%，消耗达到 8.95%；而基于模糊神经网络的控制策略 SOC 从 75%降低到 66.62%，消耗降低至 8.38%，相较于前两种策略分别实现了 1.34%和 0.57%的电量节约，相当于优化幅度分别提升 13.79%和 6.37%。在能量回收方面，Cruise 自带控制策略回收能量为 535.63kJ，基于模糊控制的策略所能回收的能量为 890.03kJ，而基于模糊神经网络的控制策略将回收能量提高到 1159.73kJ，分别多回收了 624.1kJ 和 269.7kJ 的能量。

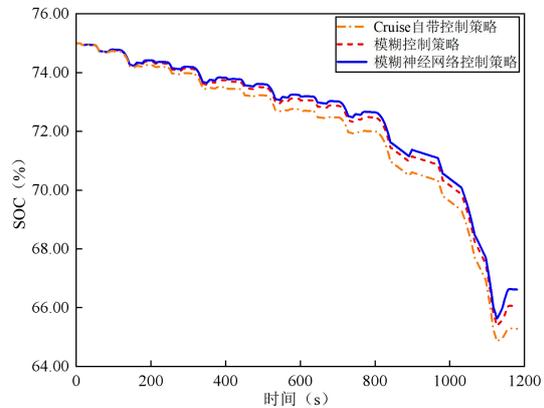


图 2 NEDC 循环工况 SOC 对比

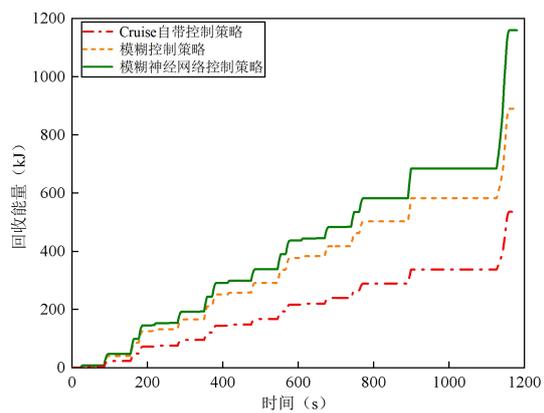


图 3 NEDC 循环工况回收能量对比

表 1 回收效果对比

控制策略	SOC 值变化 (%)	回收能量 (kJ)
Cruise 自带控制策略	75.00-65.28	535.63
模糊控制策略	75.00-66.05	890.03
模糊神经网络控制策略	75.00-66.62	1159.73

7 结论

本文所提出的基于模糊神经网络的再生制动控制方法,在典型电动汽车复杂工况下表现出优越的控制性能。该方法实现了更高的能量回收率,有效延长了整车续航里程;同时,通过对电机制动转矩的精细调节,显著改善了

整车制动过程中的平顺性,避免了制动突变和扭矩抖动等问题,提升了驾驶舒适性和安全性。此外,神经网络模块具备在线学习与动态调整能力,使系统能够根据不同驾驶行为和环境变化自适应优化控制策略,进一步增强了控制系统的智能性与鲁棒性。

参考文献

- [1]施雁云. 纯电动汽车电液复合再生制动控制策略研究[D]. 镇江: 江苏大学, 2020.
- [2]季昌健. 基于模糊神经网络的电动车再生制动力分配方法研究[D]. 长春: 吉林大学, 2020.
- [3]樊有飞. 智能汽车线控底盘技术应用研究[J]. 汽车测试报告, 2024, (20): 17-19.
- [4]张民安, 储江伟, 李春雷. 结合遗传算法的四轮电机电动车制动能量回收控制策略[J]. 重庆理工大学学报(自然科学), 2021, 35(10): 77-84.
- [5]陈超. 基于 iBooster 和 ESC 的纯电动车制动能量回收控制研究[D]. 合肥: 合肥工业大学, 2020.

作者简介: 杨品海 (2000. 8. 31-), 男, 汉, 江西赣州人, 研究生, 研究方向: 电动汽车能量回收